Gouvernement du Canada
Ministère des Communications

Government of Canada
Department of Communications

Le Centre canadien de recherche sur l'informatisation du travail
Canadian Workplace Automation Research Centre

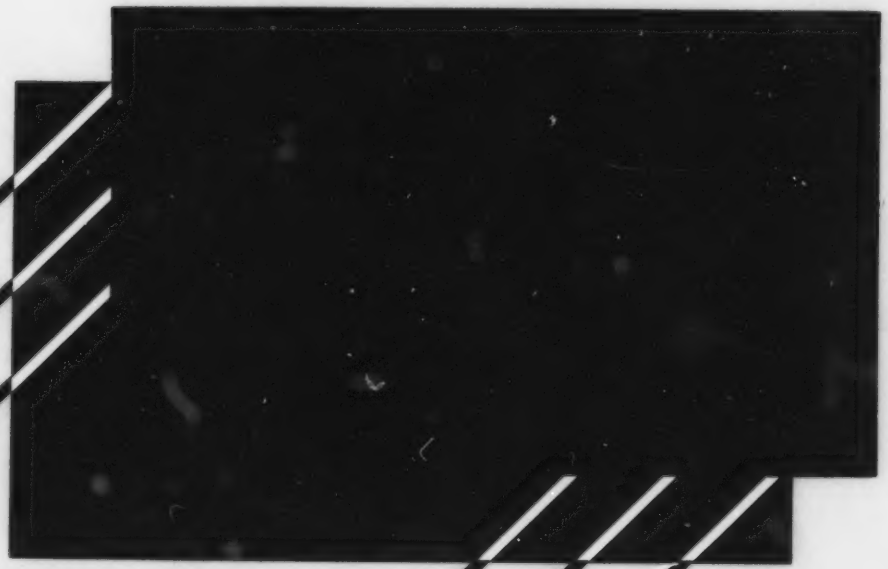

Canada

92-05727/

A SYSTEMS APPROACH TO THE EVALUATION OF EXPERT SYSTEMS

b y

Kim Dalkir

This report is the result of research done at the Canadian Workplace Automation Research Centre, Laval

Department of Communications

January 1988

No. cat. 28-1/68-1990E
ISBN 0-662-18234-0

TABLE OF CONTENTS

1. SUMMARY 1

2. INTRODUCTION 2
   - 2.1 Expert systems in government 2
   - 2.2 Expert systems in R & D project evaluation 3
   - 2.3 Satin system in France 4
   - 2.4 QUARTZ System 5

3. OBJECTIVES 5

4. TESTING METHODOLOGY 5
   - 4.1 Evaluation theory 6
     - 4.1.1 Formative and summative evaluation 6
     - 4.1.2 A systems approach to evaluation 7
     - 4.1.3 Embedding evaluation into system design 7
   - 4.2 Evaluation techniques 9
   - 4.3 Expert system evaluation 11
     - 4.3.1 Expert system metrics (objective data) 13
     - 4.3.2 Qualitative criteria (subjective data) 14
   - 4.4 Conclusions 18

5. DISCUSSION AND FUTURE WORK 18
   - 5.1 Demonstrated benefits to date 18
   - 5.2 Proposed future work 19

6. REFERENCES 21

7. APPENDIX I - Maut assessement hierarchy of evaluation criteria 23
   - 7.1 APPENDIX II - QUARTZ knowledge base matrics 25

1. SUMMARY

QUARTZ is an expert system that combines the expertise of multiple experts in the analysis and evaluation of project proposals. The system incorporates the objectives and criteria of the Quebec ERDA* program for economic regional development of Quebec firms. The expert system interactively queries users on the proposal in order to arrive at a recommendation. The system advice is printed out, along with all the information supplied by the user, facts deduced by the system and all the rules used.

This paper will focus on the developmental activities of the QUARTZ project for the three month period ending on December 1987. The emphasis is primarily on the knowledge engineering methodology used. The acquisition and representation of the knowledge for QUARTZ has been completed and is described in a previous paper (Dalkir and Muzard, 1987). The next major effort lies in the validation of this knowledge base and the evaluation of the QUARTZ system as a whole. These topics are addressed here from the point of view of evaluation theory and techniques and how these can be adapted for the evaluation of expert systems. A systems approach to expert system evaluation will be described and illustrated using QUARTZ as a case study. Finally, the lessons learned and limitations of the system will be discussed in terms of future directions to be undertaken in the project.

---

*Economic Regional Assistance Program, Department of Communications

2. INTRODUCTION

QUARTZ is an expert system intended to assist government analysts in the evaluation of project proposals submitted to the ERDA program for funding. QUARTZ will serve as a tool for the analysis stage of proposal processing. The initial prototype system will address one particular branch of the ERDA program, namely the area of innovative French language software development. The expertise represents a synergistic combination of analysts in both the Federal and Provincial Department of Communications, who are jointly responsible for the administration of this program.

2.1 Expert systems in government

The government is widely seen as the next potential client of artificial intelligence technology, after the private sector. Commercial expert systems have been successfully developed for business uses. The government already makes extensive use of very large databases, which generally consist of rules, and which require training and expertise to use. The machinations of any government are oiled by a bewildering variety of rules, regulations, procedures, laws and so on. In addition, there tends to be a significant turnover rate among civil servants, as they are lured by more lucrative positions available in the private sector. Expert systems seem the logical answer to curb this loss of expertise and as an alternative to costly and time-consuming training.

A number of benefits can accrue from the widespread use of expert systems by governments: more consistent information may be supplied to the public, professional training requirements may be decreased, professional productivity may be increased, information can be processed at a significantly reduced cost and the public will find it easier to comply with laws and regulations. Public use of expert systems should similarily help in any dealings with the public. Imagine the benefits of being able to file your tax return directly to the Revenue Department by interacting with an expert tax advisor. Another interesting role for the government may be to establish standards for expert systems. For example, by developing a knowledge base before the private sector does, governments can establish standards by which all such systems may be measured and assessed.

Some possible problems that may be encountered are that some artificial intelligence technology is still not cost-effective and requires skilled in-house staff to develop. Also, some government applications may be unique and non-transferable to the public or academic sectors. In order to avoid these pitfalls, most government research in expert systems will likely be applied rather than basic research. A good strategy advocated by Brixius (Brixius, 1984) is to establish a key prototype expert system project which will have immediate applicability and which will also be a state-of-the-art product. Applications selected should have the capability of evolving into more sophisticated systems later on.

The Canadian Workplace Automation Research Centre represents an effort by the Government of Canada to pursue this alternative type of research model. The Expert Systems Group, operating within this context, thus aims to produce systems that will be both technologically advanced and which meet a definite demand. Brixius goes on to suggest that a critical mass of 9 to 10 individuals is required in order to have sufficient creative interaction in the development of expert systems. Our group consists of approximately 15 researchers, all from varied backgrounds, who are working on a wide range of expert system applications. QUARTZ is one such project, an expert system for project evaluation.

2.2 Expert systems in R & D project evaluation

An appropriate domain for an expert system is that of research and development projects. A system to monitor the progress of commercial R&D projects, MACIE, is an example (Gallant and Balachandra, 1986). Projects must be carefully screened for their technological and commercial potential before large amounts of resources are committed to their development. In spite of this, however, many projects are never successfully completed. If such high failure risk projects could be identified early enough, then funds could be diverted to better risk projects.

There are many similarities between the domains of this project and QUARTZ. For example, criteria such as the availability of expertise, favorable disposition of interest groups, a number of possible end uses for the product; these criteria are important for project evaluation and monitoring. One important distinction, however, is that while QUARTZ was developed using "traditional" interviewing of experts, the MACIE system

used rule induction based on over 100 case studies of R&D projects under development to identify decision variables used to terminate projects.

2.3 Satin system in France

An expert system with similar objectives is also being developed by the NITAS group in France (NITAS, 1986). The SATIN system combines economic, legal and technological expertise in order to decide on the funding of innovative projects. The objective is to promote technology transfer to small and medium sized companies who would otherwise be unable to conduct such research and development activities.

There are two types of knowledge in the SATIN system: professional knowledge of financial, technical, legal and marketing aspects, and interdisciplinary knowledge on how all these aspects should be combined. Artificial intelligence technology was chosen to tackle this problem due to the changing nature of innovation. Algorithmic models would not suffice and the system is a very difficult one to simulate.

Again, there are a number of similarities with the QUARTZ expert system as there were with the MACIE system. Here, however, the difference lies not in the knowledge acquisition but in the representation of expertise. The NITAS group decided to develop a series of expert system modules that could be coordinated by a supervisory module in a coherent fashion. The modularity in the QUARTZ knowledge base is internal, in that the knowledge base is divided into 4 major branches: the technicial and innovative aspects of the product to be developed, an analysis of the economic environment for such a product, an assessment of the company that is submitting the proposal, and an evaluation of the project proposed in terms of modalities, technical and economic feasibility and management resources.

Thus expert systems in the domain of project analysis can help technology transfer agents to visualize the innovation process on a more global level. Their decision making can benefit from the expert system to produce more complete and comprehensive recommendations, as well as more easily understood ones. The universal ability of expert systems to explain the reasoning behind their conclusions, in the form of a listing of the rules used in both systems, helps users to understand the output and to decide whether or not to accept the advice received.

2.4 QUARTZ system

The QUARTZ system is presently at the stage of a first operational prototype of approximately 300 rules. The knowledge acquisition and knowledge representation stages have been completed and the system is currently in the process of being validated and evaluated. The prototype has been delivered to all the end users, along with a users manual and a feedback form to gather their comments and criticisms. In order to conduct a more systematic evaluation, a comprehensive survey of evaluation theories and methodologies was undertaken to identify the best approach for experts systems in general, and the QUARTZ system in particular.

3. OBJECTIVES

The goal is to not only validate the knowledge base of QUARTZ (are the facts and rules correct, accurate, etc.) but also to evaluate the system as a whole, both from the developers' point of view (knowledge engineers) and the users' point of view. This will lead to a refinement of the first prototype in order to develop a second operational prototype that will likely have twice as many rules and different objectives to be attained. The ultimate objective is of course user acceptance. Thus the design-evaluate-refine loop is a continual one that ceases only when the end users are satisfied with the system. The feasibility and utility of the systems or cybernetic modelling approach to evaluation of expert systems will also be investigated in conjunction with system testing.

4. TESTING METHODOLOGY

A survey of theoretical evaluation approaches and practical evaluation methodologies was conducted in order to ascertain where expert systems stand with respect to evaluation. There are many general principles of evaluation, most derived from educational research, that may be applied to expert systems. However, there are also a number of unique aspects to be considered in testing such systems. For example, expert system metrics: what should be measured in order to gauge the effect of an

expert system? The evaluation of expert systems is still in its infancy but will take on an increasing magnitude of importance as more and more research systems reach the implementation stage.

4.1 Evaluation theory

Most evaluation theories used to evaluate decision support systems are borrowed from educational evaluation and measurement literature. These, together with General Systems Theory, will be used as the foundation for a theory of expert system evaluation as an integral part of expert system design and development.

4.1.1 Formative and summative evaluation

Theories of evaluation may be described using the general dichotomy of formative vs. summative evaluation. Formative evaluation represents an attempt to relate the internal structure of a system to its external behavior to guide the developmental process. The equestion to be posed is: "What do I have to do to improve my product?" Formative evaluation is thus a prescriptive approach that concentrates on the process or means used to develop the system. The system being evaluated is thus a glass box, which, in the case of software evaluation, would contain the program code.

Summative evaluation represents a very different conceptual approach and one that yields very different data than formative evaluation. Summative evaluation evaluates performance only upon completion of the system. This includes external measures of success and is more of a diagnostic approach. The question posed in the case of summative evaluation is: "How well does the system work?" The emphasis is on outcomes and results. Cost/benefit analyses, for example, are summative evaluations of a system. The system is thus viewed as a black box with only observable behaviours or outputs used as evaluation data.

The two approaches provide different perspectives on the functioning of the system under study and should therefore be viewed as complementary rather than mutually exclusive approaches to evaluation. From a systems perspective, it is essential to implement both in order to adquately evaluate the expert system.

4.1.2 A systems approach to evaluation

The systems approach to evaluation advocates the analysis of system structure and the synthesis of these results to study system functioning ("anasynthesis") at a variety of hierarchical levels. These can be formulated as follows:

1. problem level - conceptual limits of problem addressed
2. decomposition or analysis level - identify subunits of the problem
3. plan level - description and explanation of problem solution
4. composition or synthesis - interactive functioning of system parts.

An expert system should be viewed as a sybsystem of a larger system, perhaps the work group or organization involved (see figure 1). It is very important to identify and analyse the context in which the system is expected to operate in order to effectively evaluate its performance. The larger system should also be analysed using the above tenets in order to be able to not only evaluate the validity of an expert system but also the performance and user-friendliness of the system as a whole.

Thus the evaluation should assess the effectiveness of a system (its capability to accomplish intended functions), the efficiency of the system (how well it makes use of resources in order to function) and survivability (can it continue to accomplish these functions). The conclusions reached after this research study indicate that the Viable System Theory (Beer, 1979) may provide a good theoretical basis for the evaluation of expert systems. The very criteria of reliability, maintainability and survivability of the system make expert systems ideal candidates for this conceptual approach, not only in terms of evaluation but also for the initial design.

4.1.3 Embedding evaluation into system design

A general problem with evaluation theories is that while systems are designed to meet strategic goals, evaluations tend to be almost exclusively operational in nature. It is usually not enough to simply ask whether or not a system is working properly. The underlying processes must be identified and assessed as well. For this reason, it is imperative that the evaluation of expert systems be fully embedded in the design and

development methodology. This means that performance criteria as well as test cases should be generated and agreed upon during the design stage.

Figure 1. A system's view of expert systems

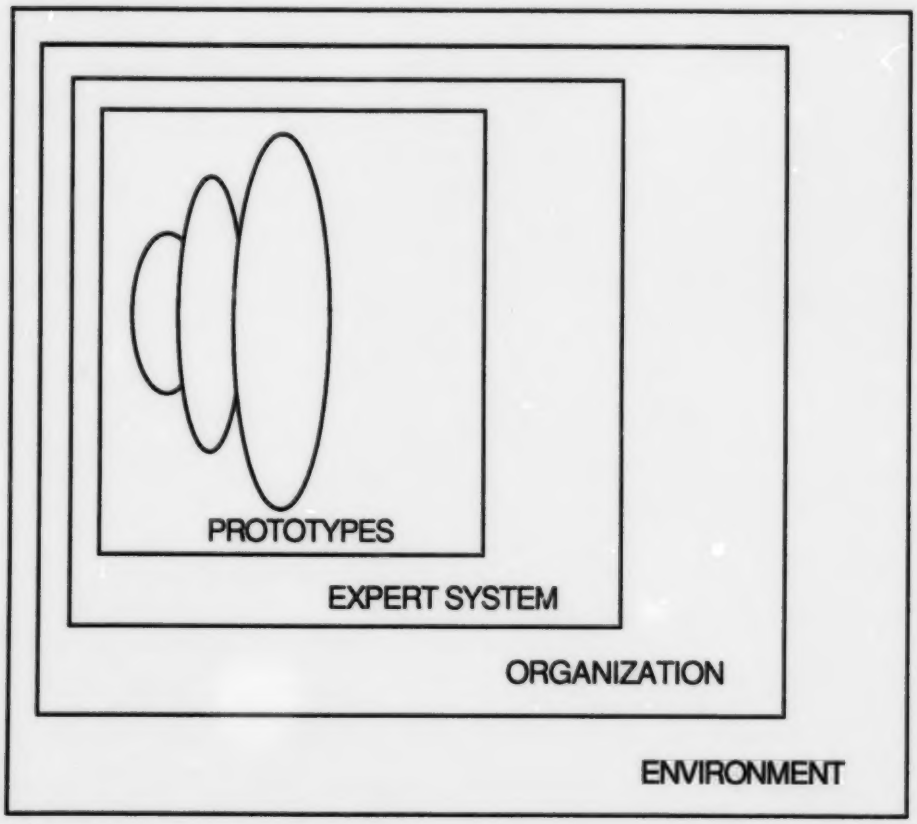

An evaluation plan should be drawn up at the outset of the project. Three levels of goals will be addressed by this plan:

1. Does the system function properly?
2. Do intended end users intend on using it?
3. Was the approach or technology used appropriate?

For example, the first level would entail checking the "correctness" of outputs by the system, the second, whether users have committed themselves to using the system and the third, was it right to use artificial intelligence technologies in the first place?

The outputs of such an integrated approach to evaluation would consist of a better understanding of the technology used to develop the system, a better overall system (incorporation of user feedback to fine tune the system) and the identification of any problem areas (e.g. system is too difficult to use).

4.2 Evaluation techniques

There are three basic principles that are common to any theory of evaluation. These are that:

1. complex processes or systems cannot be evaluated using a single criterion or single number ("score")
2. the greater the number of distinct criteria or measurements that can be taken, the better the equality of the evaluation will be
3. people will tend to disagree about the relative significance of criteria because they have different backgrounds and interests.

The evaluation technique used should be based on a number of quantitative and qualitative criteria that are sufficient to deal with the complexity of system performance. Just as the development of an expert system is a dynamic iterative process, the evaluation should be continual and adaptive. Finally, using a good sample of potential system users with varying backgrounds and interests should help to better test the system. For example, there appears to be a tendancy for potential users to concentrate on how well the system can accomodate their way of doing things (primarily subjective) while technical research and development people tend to concentrate on interface issues such as response time (primarily objective criteria). Both types need to be evaluated.

The two major evaluation techniques that can be used to evaluate both subjective and objective data are user attitude surveys and post implementation reviews. The user attitude surveys may be questionnaires or inverviews with users to measure the

amount of information and support they feel the system is providing them (subjective criteria). It should be noted here that this includes evaluation of any documentation or training that was provided along with the system. Post implementation reviews are primarily summative evaluation of how well the system does what it is supposed to do (objective criteria).

Most evaluation techniques are borrowed from software evaluation, and more specifically, from the evaluation of decision support systems. Expert systems fall under the general heading of decision aids. The problem faced is the same: how to measure improvement in decision making? Evaluation techniques address questions such as, "To what extent does the system facilitate or hinder the user's job? To what extent does it assist in the cognitive aspects of decision making? Does the system help improve the overall quality of decisions produced? What criteria should be assessed? How should they be assessed?

Some evaluation methodologies are based on decision analysis techniques such as expected value and sensitivity analysis. Others use the rational man approach, which assumes that perfect information is always available and that the optimal solution may be found using quantitative methods. An incremental approach represents a more plausible approach for expert systems. One such approach is PAM, Project Appraisal Methodology (Leibowitz, 1985). This is a combination of scoring and economic evaluation methodologies where each criterion assesses a distinct aspect of the system. While all criteria are mutually exclusive, it is not always necessary to evaluate them all in order to study the system.

Another commonly used technique to evaluate systems is MAUT, MultiAttribute Utility Theory (Adelman, 1986). An example is shown in Appendix 1. These criteria are assessed using a questionnaire with 121 questions, rated on a scale of 0 to 10 (with 0 representing strongly disagree and 10 representing strongly agree). The questionnaire has been validated and produces reliable scores. In general, the higher the overall score of a system, the better the evaluation outcome. This approach also allows a sufficiently large set of criteria to be assessed and from various different perspectives. Both PAM and MAUT appear to be good techniques for the evaluation of expert systems.

4.3 Expert system evaluation

How should expert systems be evaluated? Formative evaluation appears to be essential and has been proposed as the best means to assess expert systems (Hofmeister, 1986). However, a brief survey of how expert systems have been evaluated indicates the summative evaluation is used more often (Soloway and Littman, 1987). As previously mentioned, both are needed for any comprehensive evaluation of expert system performance.

An expert system prototype really serves as a feasibility study for the appropriateness of artificial intelligence technology to solve the given problem. An expert system is never truly "completed"; it is in a process of continual evolution. Thus summative evaluation, in the strictest sense, is impossible. Any feedback from users is not simply filed away but incorporated into the system. Formative evaluation is required to provide this developmental guidance.

It is a good idea to field test the expert system as soon as an operational prototype has been produced. This will enable the collection of evaluative data as soon as possible. The system can then be reviewed by a consultant in terms of tool selection and general system design. The primary rule set of the knowledge base can be validated to ensure knowledge is accurate, by double checking sources for factual knowledge and by having a set of experts check the heuristic knowledge. The reasoning process can be assessed using a set of test cases, developed by the users working with the knowledge engineer. A comparison can be made between system outputs and human experts working on the same set of test cases.

This preliminary assessment of reliability can check that the same user will obtain consistent outcomes over time and that different users working on the same problem will obtain consistent results. The expert system can then be progressively refined and the documentation updated to reflect any changes made.

Since it is not feasible to enumerate and evaluate all the possible inputs that can be supplied to an expert system, it is necessary to generate a representative sample of test cases. Similarily, it may be difficult to test the system with all potential end users. A good sample of users should also be selected for the evaluation of the system. In both cases, appropriate statistical methods should be used in order to obtain valid data (e.g.

adequate sample size and sampling techniques). Some possible testers may be intended end users, other knowledge engineers, graduate students, computer illiterate people and other experts (Krcmar, 1985). Each type of user should provide different sorts of data.

A good way of obtaining evaluation criteria is to have experts rate case studies or historical decisions on a variety of attributes. For example, the relative difficulty of each example, how representative it is (how likely is it to be encountered again), how much time they spent on it, and so on. This type of task analysis will generate a good range of problem types that the expert system can be tested on.

A few expert systems have reached the commercial product stage and they have been evaluated. A brief look at some of them illustrates the evaluation approaches in use today (Soloway and Littmann, 1987). The first and best known expert system, MYCIN, was evaluated using expert judgment of the accuracy of output. System performance was compared to that of experts, residents and medical students and MYCIN was found to be as good as or better than all three groups for a set of 10 challenging and real problems. The criterion used was that of percentage of correct diagnosis. This summative evaluation also found that users thought the system too difficult to use.

INTERNIST was also evaluated using summative techniques and its outputs were compared to those of human doctors. PROSPECTOR underwent a summative evaluation of its completeness and the organization of its knowledge base, again, in comparison to how human experts use the same knowledge. PROUST was run on 200 programs by novice programmers and a summative evaluation was done on the percentage of bugs detected by the intelligent tutorial system. In addition, an external evaluation of educational benefits was conducted and PROUST was found to give students a 16% advantage on exams!

R1/XCON was the only system that was assessed using formative evaluation techniques. A quarterly evaluation was done over 3 years on this developmental project that took 6 years to complete (with over 6000 rules in the knowledge base). The assessment criteria used was the percentage decrease in knowledge base factual errors and incorrect rules. Thus formative evaluation tends to be relative (always in terms of

degree of improvement over previous prototype) whereas summative evaluation renders an absolute value judgment or certification of the expert system.

4.3.1 Expert system metrics (objective data)

There has been little work done to date on developing metrics for the formal evaluation of expert systems, probably because so few of them are fully commercialized products. There are also a number of unique contributions made by expert systems that require expert appraisal to evaluate. Metrics can be used to specify a number of objective expert system parameters, however, and these can be used to identify what we want from the system, to predict what we can expect to get and to measure what we actually obtain (Kaisler, 1985). Quantitative or quantifiable criteria can also be used to measure how much actual output deviates from expected output as well as for any comparative evaluations of different systems.

Quantitative criteria are especially useful in measuring the evolutionary progress of expert systems during a formative evaluation. The two general types of metrics are application metrics, which are domain specific and technological metrics, which deal with efficiency and implementation issues, and will be specific to the shell or language used to develop the system. Some metric categories that may be useful to consider are: knowledge base complexity, knowledge base execution and system metrics.

Knowledge base complexity is used to measure the magnitude of developmental effort. Measurements may be based on the number of objects, the number of slots per frame, the number of rules, the average number of "IF" statements in a rule, and so on. Once again, borrowing from the systems approach, one can view the knowledge base as a subsystem of the expert system. The system complexity is generally definied as (N-1)/S, where N represents the number of nodes or decision points, and S represents the number of links between the nodes. This can be modified slightly to fit the knowledge representation scheme used to yield N as the number of objects and S as the number of schema for example. (Appendix 2 provides the complexity measures for the three knowledge bases developed for the QUARTZ system.)

Knowledge base execution metrics measure such things as the time required to start up the system, to update the system and to respond to user commands. Execution

metrics measure the overall speed of knowledge processing, the number of rules considered per conclusion, the amount of information in individual rules, the average consultation time per user, the number of distinct concepts represented in the knowledge base, etc.

A number of important issues must be taken into consideration in the quantitative evaluation of esxpert system. These are:

- metrics cannot be static since the system is evolving and growing
- the tools used to develop the system must also be evaluated
- the number and types of problems the system can solve should be identified and assessed with respect to accuracy and reliability
- the redesign effort should be measured (how much needs to be changed e.g. number of rules per modification).
- trend analysis from incremental snapshots of the system as it evolves (e.g. graph of knowledge base complexity vs. time).

These measurements can tell us whether the knowledge base is too complicated, too simple, which is an indication of how appropriate expert system technology was for the problem, whether users are spending too much time or too little time with the system (should be comparable to time spent with human expert, approximately 20 minutes per consultation). A different sort of metric may be to measure knowledge engineering efficiency in terms of number of rules per day (or number of days per rule!). However, while quantitative measurements are necessary, they are not sufficient to evaluate the unique aspects of expert system. Qualitative or subjective data must also be obtained.

4.3.2 Qualitative criteria (subjective data)

A generally accepted set of qualitative or subjective criteria to evaluate expert systems has yet to be developed. There are a large number of criteria that may be borrowed from conventional software evaluation such as portability, augmentability, cost effectiveness and so forth. In addition, criteria specific to expert system technology will have to be added to the list. A taxonomy of criteria proposed by Krcmar (Krcmar, 1985) will be used to organize the large number of applicable criteria.

This taxonomy consists of three general categories: technical aspects (the hardware and software used to develop the system), the knowledge base (the validity of the facts and rules used by the system) and what are termed environmental or human factors (management awareness, user acceptance, cost/benefit/risk analysis, etc.). A list of the most important criteria in each category is given in the table below.

Table 1. Qualitative evaluation criteria for expert systems

Technical Aspects

- flexibility and ease of modification of expert system as the environment changes (for example, system objectives are no longer the same)
- does the addition of more knowledge call for major modifications?
- ability of system to grow as more expertise and feedback is obtained
- reliability of system functioning (e.g. does it crash?)
- efficiency of resource utilization by system (e.g. memory use)
- device independence or portability (can the system be run on different hardware configuration?)
- system intelligibility or understandability (can the code be read easily?)
- testability (how easy is it to test system functioning?)
- ease of interaction with the system (technical quality of the interface)

Knowledge Base

- validity range of knowledge base (what problems can be solved?)
- understandable to both users and developers (e.g. phrase ambiguities)
- accuracy of content (usually determined by domain experts)
- quality of system deductions and advice
- correctness of reasoning techniques used
- does it produce useful results? (e.g. report format)
- ease of interaction (e.g. help facilities)
- non technical quality of interface (e.g. windows, highlighting)
- completeness of knowledge base (any unsolvable cases?)
- consistency of knowledge base (e.g. uniform terminology, notation)
- structuredness of knowledge base (e.g. how well organized is it?)

- self-descriptiveness (enough information in the knowledge base to identify objectives, assumptions, constraints, status at any given point?)
- were conflicts resolved in an adequate manner? (e.g. were all conflicts among experts resolved or were metamodels of expertise built? if the latter, are users given the choice of expert to consult in the system?)
- can you distinguish between a good knowledge base and a poor inference engine and the case of a poor knowledge base but with good inferencing?
- is the knowledge representation too rich? too simple? compatible with experts' knowledge organizations?

Human or Environmental factors

- do users accept the system?
- do users intend to use the system?
- do users trust system functioning and outputs?
- does the system help users in their work?
- since users are not prone to adapting themselves to meet the needs of any system, can the system adapt to the current user, context, level of expertise and strategy preferences?
- can the expert system be extended for use in other applications? by other user groups? (how generic or specialized is the product?)
- was the design time acceptable to developers? to users? to management?
- does the system work well from the point of view of users, knowledge engineers, outside consultants?
- have user suggestions been incorporated into the system?
- is the system cost effective?
- what are the benefits of the system? (e.g. retention of corporate expertise, training, better and more consistent decision making, better quality of work life, avoidance of errors, savings in time, improvement in communication among human users, ability to serve a wider client base).
- what are some of the risks associated with system use? (e.g. legal liability)
- what were the costs involved? (development cost, delivery cost and maintenance costs)

It is also important to be aware of the major reasons why expert systems fail. The criteria of appropriateness appears to play the largest role in the success or failure of

such systems. The reason most systems are never successfully implemented is because the problem addressed was not an appropriate one. Either the problem was not well understood, or it requires commonsense reasoning; it may be that there is no solution (not even human experts can find one) or that we're faced with the closed world problem, namely, that the system does not know what it does not know (unlike, say, a human doctor who knows when to recommend that you see another type of specialist).

User acceptance is usually the final deciding hurdle where expert systems are concerned. In order to maximize the chances of success, the system must be designed in a way that is testable, users must trust the system and they must not believe that it will replace them in their jobs.

Some other reasons why users may not accept the expert system are:

- unfamiliarity with computer technology
- difficulty in adjusting to the user interface
- belief that humans can do the job better without the system
- belief that they need only use it for very difficult cases
- tendancy to remember any previous problems encountered with systems use (no matter how trivial!)
- lack of trust or too much trust in output
- dimunition of job satisfaction

It has been historically demonstrated (Lane, 1986) that the introduction of any innovation into an existing system must take into account the willingness of intended users to accept the innovation and to integrate it into their job structure. There is still a lot of distrust where computers are concerned and the most critical issue of all may be the degree of transparency or opacity of the expert system's reasoning process. As long as users feel they can adequately access the inner working or logic which the system uses in giving them advice, the more likely they are to feel at ease with it. This places a great deal of emphasis on the explanation facility of the expert system (the ability to answer how and why questions).

4.4 Conclusions

The complete evaluation of a system requires both objective and subjective measurements. Objective measurements comprise error analysis, time on task and usage patterns while subjective measurements concern the reliability of system performance, how helpful it is how dogmatic it is, whether or not it can adequately justify its conclusions and so on. Since both user acceptance and system performance are needed for an expert system to succeed, both formative and summative evaluation must be undertaken. At present, there still appears to be a great need for substantial research to develop quantitative and qualitative measures of an expert system. A systematic way of capturing and incorporating both diagnosis and prescriptive user feedback is required for the evaluation of expert systems. An interesting development along these lines is the EVA system (Expert system Validation Associate), an automatic validation system for expert systems (Stachowitz and Combs, 1987).

5. DISCUSSION AND FUTURE WORK

5.1 Démonstrated benefits to date

QUARTZ has already demonstrated its value in the retention of corporate expertise in that several of the original experts are no longer working on ERDA project assessments. Their particular area of expertise, together with their overall prespective on proposal analysis, remain a part of the QUARTZ knowledge base. Similarly, QUARTZ has served as a successful feasibility study for the use of expert systems to monitor the life cycle of a project proposal.

There appear to be a number of potential spinoff systems from the QUARTZ expert system. QUARTZ may be modified to yield an expert system to analyze project proposals for the Manitoba ERDA program, for example, or for inhouse analysis of proposals at our own research centre. It is also conceivable that QUARTZ could be used directly by companies wishing to have assistance in the preparation of their proposals. This would represent a step in the direction of having the public sector improve the accessibility of information to the public it serves.

Finally, the QUARTZ knowledge base should help produce more consistent and more comprehensive analysis, and recommendations that are based on a more systematic analysis or all the relevant qualitative and quantitative criteria. This formalized expertise can also be made available to beginning analysts as a job aid or training tool. The Quebec city group of experts have agreed to help investigate this possible application of QUARTZ further. The major benefit expected to accrue from the QUARTZ system is an overall increase in the efficiency and quality of the feedback that can be given to the companies concerned.

The benefits outlined here will be evaluated in the next trimester of work and will be based on the methodologies discussed in this report.

5.2 Proposed future work

The research conducted in these past three months has served to formulate a sound theoretical basis for the formative evaluation of QUARTZ prototypes. The systems approach to evaluation, as well as the perspective that an expert system should be a viable system, also appears to be a justified and pragmatic approach to the development and validation of expert systems. The evaluation of QUARTZ will thus proceed along the suggested lines of embedding the evaluation process in the design of the system and will make use of the quantitative and qualitative criteria identified in Appendix I. Once user acceptance of a prototype has been obtained, a summative evaluation will be carried out on this "final" version of QUARTZ.

The lessons learned from this study of evaluation methods indicates that QUARTZ should be tested on at least 4 different levels. These include, in order of increasing generality:

1. knowledge base of facts and rules; inferencing mechanism; user interface
2. expert system as a whole - its inputs, throughputs, outputs
3. analysis subsystem of the ERDA program - efficiency, quality
4. the ERDA decisional process as a whole.

Some milestones to be attained in the next trimester include:

- validation of the knowledge base using both original experts and different ones (for example, expert at our own research centre)
- evaluation of system performance, from the point of view of users (questionnaire data and individual interviews)
- measurement of system metrics to gauge the developmental effort required.

The next step is to prepare an evaluation plan for QUARTZ. Some of the major milestones envisioned in the next few months will include the validation and reliability testing of this feedback questionnaire, incorporation of user suggestions and corrections and the delivery of the second operational prototype.

6. REFERENCES

Adelman, L. (1986). On the Basis of What Criteria Should Decision Support Systems Be Evaluated? Proceedings, Expert Systems in Government Symposium. Washington, D.C. pp. 348-350.

Bell, M. (1985). Why Expert Systems Fail. Journal of Operational Research Society, 36, 7, 613-619.

Borg, W. and Gall, M. (1983). Educational Research (4th ed.) New York: Longman, Inc.

Beer, S. (1979). The Heart of Entreprise. Devon: Pitman Press.

Brixius, L (1984). Artificial Intelligence Applications in Civil Government. Proceedings IEEE EASCON'84 Conference. pp. 45-49.

Dalkir, K. and Muzard, J. (1987). QUARTZ: an intelligent assistant for the analysis and evaluation of project proposals. Proceedings IEEE Montech COMPINT'87 conference. Montreal, Quebec. pp. 208-210.

Defense Systems, Inc. The Decision Aid Measurement and Evaluation (DAME) Methodology Assessment of the Integrated Tactical Decision Aid (ITDA). 29 Apr. 1985.

Gallant, S. and Balachandra, R. (1986). Using Automated Techniques to Generate an Expert System for R & D Project Monitoring. IFAC Conference on Economics and Artificial Intelligence. Aix-en-Provence, France. pp. 61-66.

Gieszl, L. (1987). The Expert System Applicability Question. Proceedings, Artificial Intelligence and Simulation Conference. San Diego, CA. 17-20.

Gordon, S. (1988). The Human Factor in Expert Systems. AI Expert, January, 1988, pp. 55-59.

Hofmeister, A. (1986). Formative Evaluation in the Development and Validation of Expert Systems in Education. Comput. Intell., 2, 65-67.

Kaisler, S. (1985). Expert System Metrics. Proceedings Expert Systems in Government Symposium, Washington, D.C. pp.114-119.

Kremar, H. (1985). Enterprise-wide Information Management: Expert Systems for Information Management. IBM LA Scientific Centre, Report G320-2767.

Lane, N. (1986). Global Issues in the Evaluation of Expert Systems. Proceedings IEEE Conference on Systems, Man and Cybernetics. Alexandria, VA. pp. 121-125.

Leblanc, L. (1987). An Analysis of Critical Success Factors for a Public Sector Decision Support System. Evaluation Review, 11, 1, 73-83.

Liebowitz, J. (1985). Evaluation of Expert Systems: an approach and case study. Proceedings 2nd Annual Conference on Artificial Intelligence Applications: the engineering of knowledge-based systems. Miami Beach, Florida, December 1985.

NITAS (1986). A Reasoning System for the Guidance of Technological Transfer. IFAC Conference on Economics and Artificial Intelligence. Aix-en-Provence, France. pp. 183-186.

Soloway, E. and Littman, D. (1987). Expert System Evaluation. Tutorial, IJCAI87 Conference, Milan, Italy.

Stachowitz, R. and Combs, J. (1987). Validation of Expert Systems. Proceedings of the 20th Annual Hawaii International Conference on System Sciences, 1987.

7 APPENDIX I. MULTIATTRIBUTE UTILITY ASSESSMENT HIERARCHY OF EVALUATION CRITERIA

(From, Adelman, L. (1986). On the Basis of What Criteria Should Decision Support Systems Be Evaluated? Procs. ESIG conference.)

0. overall utility (6)

1. system/user interface

1. match with personnel
   1. training and technical background (3)
   2. work style, workload and interest (4)
   3. operational needs (5)
2. system characteristics
   1. general
      - ease of use (4)
      - understanding system processes (3)
      - ease of training (2)
      - response time (2)
   2. specific
      - user interface (2)
      - completeness of data files (3)
      - accuracy of expert judgments (2)
      - ability to modify judgments (2)
      - understanding of system algorithms (2)
      - utility of graphs (2)
      - utility of printouts (2)
      - understanding of text (2)

2. user-system/organization interface

1. efficiency factors
   1. acceptability of time for
      - task accomplishment (3)
      - data management (2)
      - set-up requirements (2)
   2. perceived reliability under real conditions (2)

skill availability (2)
hardware availability (2)

2. match with organizational factors
   1. effect on organizational structure and procedures (2)
   2. effect on other people's positions in the organization
      political acceptability (2)
      other peoples' workload (2)
   3. effect on information flow (2)
   4. side effects
      value in performing other tasks (2)
      value to related organizations (2)
      training value (2)

3. organization/environment interface

1. decision accuracy (8)
2. match between system's technical approach and problem aspects (7)
3. decision process quality (2)
   1. quality of framework for incorporating judgment (2)
   2. range of alternatives (2)
   3. weighting of consequences or alternatives (2)
   4. assessment of consequences or alternatives (3)
   5. re-examination of decision making process (3)
   6. use of information (3)
   7. consideration of implementation and contingency plan (2)
   8. effect on group discussions (3)
   9. effect on decision maker's confidence (2)

Note: numbers in parentheses indicate the number of questions used in the questionnaire to assess that criterion.

7.1 APPENDIX II. EVOLUTION OF STRUCTURAL COMPLEXITY OF QUARTZ KNOWLEDGE BASE

Version date	# object	# schemas	complexity	# rules
FÉVRIER 87	83	30	2.73	15
MARS 87	58	17	3.35	108
MAI 87	82	21	3.86	260

STRUCTURAL COMPLEXITY

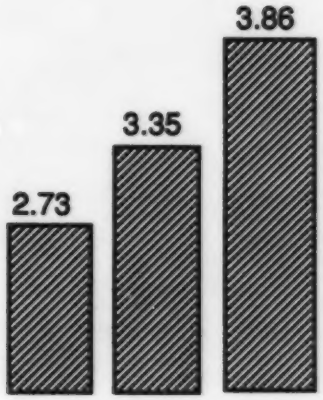

NUMBER OF RULES

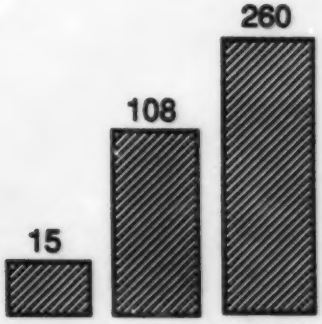

Gouvernement du Canada
Ministère des Communications

Government of Canada
Department of Communications

Le Centre canadien de recherche sur l'informatisation du travail
Canadian Workplace Automation Research Centre

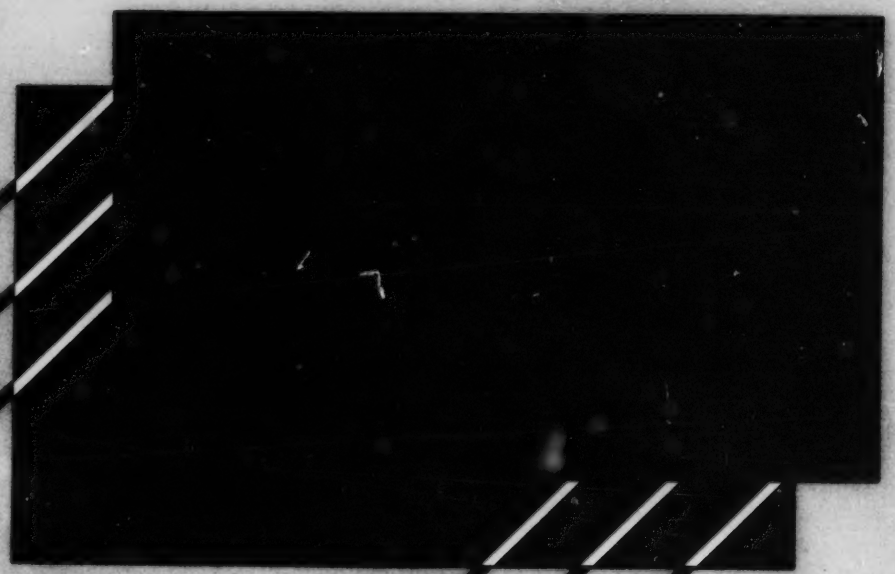

Canada

APPROCHE SYSTÉMIQUE DE L'ÉVALUATION DES SYSTEMES EXPERTS

par

Kim Dalkir

Ce rapport est le résultat de recherches effectuées
au Centre canadien de recherche sur l'informatisation du travail (CCRIT) Laval

Communications Canada

Janvier 1988

No. cat. 28-1/68-1990F
ISBN 0-662-96425-X

TABLE DES MATIERES

1. RÉSUMÉ 1

2. INTRODUCTION 2
   2.1 Systèmes experts au gouvernement 2
   2.2 Systèmes experts pour l'évaluation de projets de R & D 3
   2.3 Le systèmes Satin en France 4
   2.4 Le système QUARTZ 5

3. OBJECTIFS 5

4. MÉTHODOLOGIE DES ESSAIS 6
   4.1 Théorie de l'évaluation 6
      4.1.1 Évaluation formative et sommative 6
      4.1.2 Approche systémique de l'évaluation 7
      4.1.3 Intégration de l'évalution dans la conception des systèmes 8
   4.2 Techniques d'évaluation 9
   4.3 Évaluation des systèmes experts 11
      4.3.1 Métrologie des systèmes experts (données objectives) 14
      4.3.2 Critères qualitatifs (données subjectives) 15
   4.4 Conclusions 19

5 ANALYSE ET TRAVAUX FUTURS 20
   5.1 Avantages démontrés 20
   5.2 Projets de travaux 21

6. RÉFÉRENCES 22

7. APPENDICES I - HIÉRARCHIE DES CRITERES D'ÉVALUATION DE LA THÉORIE MULTI-ATTRIBUT DE L'UTILITÉ (MAUT) 24
   7.1 APPENDICES II - MÉTROLOGIE DE LA BASE DE CONNAISSANCES QUARTZ 26

1. RÉSUMÉ

QUARTZ est un système multi-expert qui renferme le savoir de plusieurs experts dans les domaines de l'analyse et de l'évaluation des projets. Il contient les objectifs et critères du programme EDER* du Québec pour le développement économique régional de firmes du Québec. Les utilisateurs par le biais de l'interrogation interactive dans le cadre des propositions soumises, amènent le système expert à cumuler les renseignements qui permettent d'en arriver à une recommandation. Les résultats de la consultation s'impriment avec les renseignements fournis par l'utilisateur, les déductions du système à partir des faits, les règles appliquées et bien sur la recommandation.

Dans le présent rapport, nous décrivons les travaux de développement du projet QUARTZ qui se sont déroulés au cours du dernier trimestre de 1987, en mettant surtout l'accent sur la méthodologie de génie cognitif utilisée. L'acquisition et la représentation des connaissances dans le système QUARTZ sont terminées; elles sont décrites dans un article précédent (Dalkir et Muzard, 1987). Les deux grandes étapes suivantes sont la validation de la base de connaissances et l'évaluation globale du système QUARTZ lui-même. Nous les abordons ici par une étude de la théorie et des techniques d'évaluation et de leur application aux systèmes experts. Nous décrivons une approche systémique de l'évaluation des systèmes experts que nous illustrons avec l'exemple du système QUARTZ. En conclusion, nous formulons les leçons attirées ainsi que les limites du système et proposons des travaux pour la poursuite du projet.

---

* Entente de développement économique et régional

2. INTRODUCTION

QUARTZ est un système expert d'aide au profit des analystes du gouvernement qui doivent évaluer les demandes de subvention dans le cadre du programme EDER. QUARTZ servira d'outil à l'étape de l'analyse du traitement des propositions. Le prototype initial du système sera appliqué à l'évaluation de projets EDER d'un domaine particulier, soit celui du développement de logiciels innovateurs en langue française. L'expertise englobe le savoir combiné des analystes des ministères des Communications de gouvernements fédéral et provincial, qui conjointement sont responsables de l'administration de ce programme.

2.1 Systèmes experts au gouvernement

Le gouvernement est largement vu comme le deuxième plus important client éventuel de la technologie de l'intelligence artificielle, après le secteur privé. Des systèmes experts commerciaux sont déjà exploités avec succès dans l'industrie. Le gouvernement utilise déjà de très grandes bases de données, formées généralement de règles et dont l'exploitation exige de la formation et des connaissances. Toute machine gouvernementale a besoin, pour tourner, d'une infinité de règles, règlements, procédures, lois, etc. Par ailleurs, il y a une tendance à une grande mobilité parmi les fonctionnaires qu'attirent les promesses de situations plus lucratives dans le secteur privé. Les systèmes experts semblent être la solution logique à ce problème de perte d'expertise et un choix possible pour éviter la formation longue et coûteuse.

L'usage généralisé de systèmes experts dans les gouvernements peut présenter un certain nombre d'avantages : offrir au public une information plus uniforme; réduire les exigences de formation professionnelle augmenter la productivité professionnelle, réduire les coûts de traitement de l'information et faciliter au public l'observance des lois et des règlements L'usage généralisé des systèmes experts faciliterait aussi les relations avec le public. Imaginez comme ce serait facile pour vous de présenter votre déclaration d'impôt directement au ministère du Revenu en dialoguant avec un expert-conseil fiscal. Un autre rôle intéressant pour le gouvernement peut consister à établir les standards des systèmes experts. Par exemple, en développant une base de connaissances avant que ne le fasse le secteur privé, les gouvernements peuvent

établir des standards suivant lesquelles seraient mesurées et évaluées toutes ces bases de connaissances.

Malheureusement, la technologie de l'intelligence artificielle reste coûteuse et exige le développement de compétences internes. Aussi, certaines applications gouvernementales peuvent être spécifiques, donc non transférables au domaine public ou universitaire. Pour éviter de tels écueils, la recherche sur les systèmes experts au gouvernement sera vraisemblablement plus appliquée que fondamentale. Selon Brixius [Brixius, 1984], une bonne stratégie consisterait à créer un prototype clé de système expert qui aurait des applications immédiates et qui serait un produit de pointe. Les applications choisies devraient être évolutives afin de pouvoir devenir plus tard des systèmes plus complexes.

Le Centre canadien de recherche en informatisation du travail représente une tentative de la part du gouvernement du Canada de poursuivre ce type alternatif de modèle recherche. Le Groupe des systèmes experts, qui oeuvre dans ce contexte, vise ainsi à produire des systèmes qui sont évolués technologiquement et qui, en même temps, répondent à une demande définie. Il faut, toujours selon Brixius, une masse critique de 9 à 10 individus pour obtenir l'interaction créative suffisante exigée pour le développement d'un système expert. Notre groupe comprend approximativement 15 chercheurs, de formation différente, qui travaillent sur un grand nombre d'applications de systèmes experts, différentes. QUARTZ est une de ces applications, un système expert pour l'évaluation des projets.

2.2 Systèmes experts pour l'évaluation des projets de R & D

Un domaine tout indiqué pour les systèmes experts est celui des projets de recherche et développement. Conçu pour suivre l'avancement des projets de R & D commerciaux, MACIE, est un exemple de système expert appliqué à ce domaine. [Gallant et Balachandra, 1986]. Les projets doivent être soigneusement choisis pour leur potentiel technologique et commercial avant qu'on engage des ressources substantielles dans leur développement. Malgré ce filtrage préalable, de nombreux projets n'aboutissent jamais. Si l'on pouvait, dès le départ, identifier les entreprises à haut risque d'échec, on pourrait utiliser les fonds à des projets moins risqués.

Il y a une grande ressemblance entre les domaines de MACIE et QUARTZ. Prenons, par exemple, les critères de disponibilité de l'expertise, de disposition favorable des groupes visés, de nombre possible d'applications pour le produit; ces critères sont importants pour l'évaluation et le contrôle des projets. Une distinction importante entre les deux cependant vient de ce que QUARTZ a été mis au point au moyen d'interviews classiques d'experts, tandis que le système MACIE a utilisé l'induction de règles à partir de plus de 100 études de cas de projets de R & D différentes pour en arriver aux variables de décision qui ont déterminé la conclusion des projets.

2.3 Le système Satin en France

Un système expert visant les mêmes objectifs est en cours de développement en France; il est l'oeuvre du groupe NITAS [NITAS, 1986]. Le système SATIN réunit de l'expertise en économie, en juridique et en technologie pour décider du financement de projets innovateurs. Son objectif est la promotion du transfert technologique vers les petites et moyennes entreprises, qui, sans cette aide, ne seraient pas en mesure de poursuivre de telles activités de recherche et développement.

Le système SATIN contient deux types de connaissances : une connaissance professionnelle des aspects financier, technique, juridique et commercial et une connaissance interdisciplinaire sur la manière dont tous ces aspects doivent être regroupés. La technologie de l'intelligence artificielle a été choisie pour résoudre le problème en raison de la nature changeante de l'innovation. Les modèles algorithmiques ne suffiraient pas et le système est très difficile à simuler.

Comme MACIE, le système SATIN présente un certain nombre de similitudes avec le système expert QUARTZ. Mais, ici, la différence n'est plus dans l'acquisition des connaissances mais dans leur représentation. Le groupe NITAS a décidé de développer une série de modules de systèmes experts que viendrait coordonner un module superviseur de manière cohérente. La modularité dans le système QUARTZ est interne; en effet, c'est sa base de connaissances qui est divisée en quatre domaines : comme les aspects techniques et innovateurs du produit à développer, l'analyse de l'environnement économique du produit, l'évaluation de l'entreprise qui soumet le projet et l'évaluation du projet en termes de modalités, de faisabilité technique et économique et de ressources de gestion.

Ainsi, les systèmes experts dans le domaine de l'analyse des projets peuvent aider les agents de transfert technologique à visualiser le processus d'innovation à un niveau plus global et à produire des recommandations plus complètes, exhaustives, ainsi que plus faciles à comprendre. L'aptitude universelle des systèmes experts à dévoiler le raisonnement sous-jacent à leurs conclusions, sous la forme d'une liste des règles utilisées dans les deux systèmes, aide l'utilisateur à comprendre le résultat et à décider s'il acceptera ou non le conseil reçu.

2.4 · Le système QUARTZ

Le système QUARTZ est actuellement au stade d'un premier prototype opérationnel d'environ 300 règles. Les étapes d'acquisition et de représentation des connaissances sont terminées et actuellement la validation et l'évaluation du système suivant leur cours. Le prototype a été livré aux utilisateurs finals avec un guide d'exploitation et une formule d'évaluation qui servira à recueillir leurs remarques et critiques. Afin de réaliser une évaluation plus systématique, nous avons entrepris une étude exhaustive des théories et méthodologies d'évaluation pour déterminer la meilleure approche auprès des systèmes experts en général et du système QUARTZ en particulier.

3. OBJECTIFS

Le but est non seulement de valider la base de connaissances de QUARTZ (est-ce que les faits et règles sont corrects, précis, etc.) mais également, d'évaluer le système en entier, du point de vue des réalisateurs (des ingénieurs de la connaissance) comme de celui des utilisateurs. Ensuite, il y aura raffinement du premier prototype et développement d'un deuxième prototype opérationnel qui, vraisemblablement, aura deux fois plus de règles et des objectifs. L'objectif ultime est, bien sûr, l'accord de l'utilisateur. Ainsi, la boucle conception-évaluation-raffinement est une boucle continue qui ne s'arrête que lorsque les utilisateurs finals sont satisfaits du système. La faisabilité et l'utilité de l'approche de modélisation systémique ou cybernétique pour l'évaluation des systèmes experts seront également examinées au cours de l'essai du système.

4. MÉTHODOLOGIE DES ESSAIS

Nous avons fait une étude des théories et méthodologies pratiques de l'évaluation pour savoir où en est l'évaluation des systèmes experts. Il y a de nombreux principes généraux de l'évaluation, la plupart dérivés de la recherche en éducation, qui peuvent s'appliquer aux systèmes experts. Ceux-ci ont cependant un certain nombre de particularités dont il faut tenir compte au moment de leur essai. Ainsi la métrologie des systèmes experts : que doit-on mesurer pour évaluer les effets d'un système expert? L'évaluation d'un système expert en est encore à ses premiers balbutiements mais elle prendra une importance de plus en plus grande à mesure que les systèmes de recherche arriveront au stade de l'implantation.

4.1 Théorie de l'évaluation

La plupart des théories d'évaluation utilisées pour évaluer les systèmes d'aide à la décision sont empruntées aux ouvrages d'évaluation et de mesure en éducation. Nous nous inspirerons de ces théories, ainsi que de la théorie générale des systèmes, pour bâtir une théorie d'évaluation des systèmes experts, intégrée à la conception et au développement de ces systèmes.

4.1.1 Évaluation formative et sommative

Nous pouvons décrire les théories d'évaluation selon la dichotomie générale d'évaluation formative ou sommative. L'évaluation formative représente une tentative de relier la structure interne d'un système à son comportement externe en vue de guider le processus de développement. La question à poser est la suivante : "Que dois-je faire pour améliorer mon produit?" L'évaluation formative est ainsi une approche prescriptive qui se concentre sur le procédé ou moyen utilisé pour développer le système. Le système évalué est, ici, une boîte de verre qui, dans le cas de l'évaluation de logiciels, contiendrait le code du programme.

L'évaluation sommative représente une approche conceptuelle très différente et donne un résultat très différent de l'évaluation formative. L'évaluation sommative ne

mesure la performance du système que lorsqu'il est complet. Elle donne des mesures externes du succès, sous forme de diagnostiques. La question posée en évaluation sommative est : "Le système fonctionne-t-il bien?". L'accent est sur le produit, le résultat. Les analyses coût-bénéfices, par exemple, sont des évaluations sommatives. Le système évalué est ainsi vu comme une boîte noire et seuls les comportements ou résultats observables sont utilisés comme données d'évaluation.

Les deux approches offrent des perspectives différentes du fonctionnement du système étudié et devraient donc être considérées comme complémentaires et non comme mutuellement exclusives. D'un point de vue global, il est essentiel de les appliquer toutes deux afin d'évaluer adéquatement le système expert.

4.1.2 Approche systémique de l'évaluation

L'approche systémique de l'évaluation préconise l'analyse de la structure du système et la synthèse des résultats pour étudier le fonctionnement du système ("l'anasynthèse") à différents niveaux hiérarchiques, soit :

1. le niveau du problème - limites conceptuelles du problème étudié
2. niveau de décomposition ou d'analyse - subdivision du problème
3. niveau du plan - description et explication de la solution du problème
4. composition ou synthèse - interactivité des parties du système.

Un système expert doit être vu comme un sous-système d'un système plus grand, tel le groupe de travail ou l'organisation intéressée (voir figure 1). Il est très important de définir et d'analyser le contexte dans lequel le système doit fonctionner afin d'évaluer efficacement son rendement. Il est aussi important d'analyser le grand système selon les même principes, afin d'être en mesure non seulement d'évaluer le système expert mais aussi le rendement et l'utilisation possible du système entier.

Ainsi, l'évaluation doit mesurer l'efficacité du système (jusqu'à quel point permet-il d'accomplir les fonctions prévues?), son efficience (de quelle manière exploite t-il les ressources pour fonctionner?) et sa viabilité (peut-il continuer à accomplir ces fonctions?). Les conclusions auxquelles est arrivée l'auteure de cette étude indiquent que la "théorie du système viable" [Beer, 1979] peut constituer une bonne base

théorique pour l'évaluation des systèmes experts. Les critères de fiabilité, de conservation et de viabilité du système font des systèmes experts des candidats idéals pour cette approche conceptuelle, non seulement pour ce qui est de l'évaluation, mais aussi pour la conception initiale.

4.1.3 Intégration de l'évaluation dans la conception des systèmes

Si la conception des systèmes vise des objectifs stratégiques, les évaluations, elles, tendent généralement à être presque exclusivement opérationnelles de nature. Il ne suffit pas de se demander si le système fonctionne convenablement : il faut également définir les processus sous-jacents et les évaluer. D'où la nécessité d'intégrer entièrement l'évaluation des systèmes experts dans la méthodologie de conception et de développement, et donc de s'entendre sur les critères de rendement et sur les jeux d'essai dès le stade de la conception.

Un plan d'évaluation doit être élaboré au début du projet. Trois niveaux d'objectifs doivent être traités dans ce plan :

1. le système fonctionne-t-il convenablement?
2. les utilisateurs finals visés comptent-ils l'utiliser?
3. l'approche ou la technologie utilisée est-elle appropriée?

Par exemple, le premier niveau consisterait à faire vérifier les résultats par le système; le deuxième, à vérifier si les utilisateurs se sont engagés à employer le système et le troisième, s'il était indiqué, au départ, de recourir aux technologies de l'intelligence artificielle?

Cette approche intégrée de l'évaluation donnerait une meilleure compréhension de la technologie utilisée pour développer le système, un meilleur système en général (la réaction de l'utilisateur servirait à affiner le système) et ferait ressortir les difficultés (par exemple, le système est-il trop difficile à utiliser?).

Figure 1. Vue systémique des systèmes experts

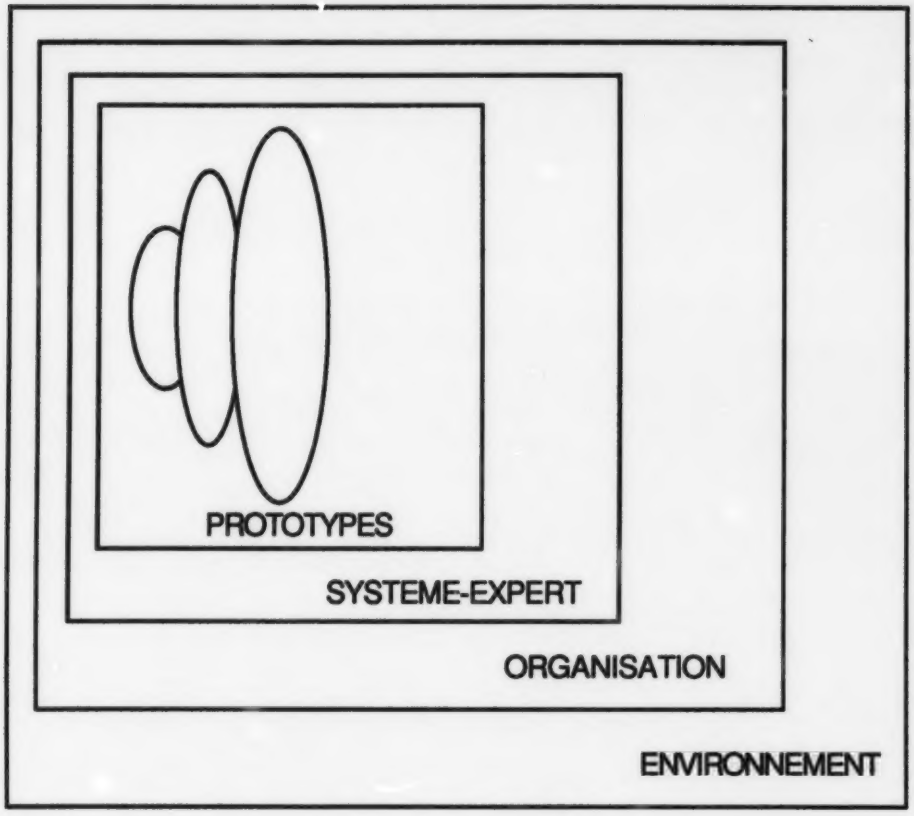

4.2 Techniques d'évaluation

On retrouve dans toutes les théories d'évaluation trois principes de base. Il s'agit des principes suivants :

1. Aucun processus ou système complexe ne peuvent être évalués à l'aide d'un seul critère ou d'un seul chiffre ("une seule note")
2. Plus nombreux sont les critères, et plus les mesures à prendre le sont aussi, meilleure sera la qualité de l'évaluation
3. L'unanimité n'est pas rencontrée quant à la signification relative des critères parce que les personnes n'ont pas la même formation ou expérience ni les mêmes intérêts.

La technique d'évaluation utilisée doit être basée sur un nombre de critères quantitatifs et qualitatifs suffisant par rapport à la complexité de la performance du système. Tout comme le développement d'un système expert est un processus itératif dynamique, l'évaluation doit être continue et adaptative. Finalement, en choisissant un bon échantillon d'utilisateurs potentiels du système, avec une expérience et des intérêts variés, on réussirait à mieux tester le système. Par exemple, il semble y avoir une tendance parmi les utilisateurs potentiels à se concentrer sur la manière dont le système peut s'adapter à leurs méthodes (critères principalement subjectifs), tandis que les chercheurs se penchent surtout sur les questions d'interface, comme le temps de réponse (critères principalement objectifs). Les deux aspects doivent être évalués.

Les deux principales techniques d'évaluation qui peuvent servir à évaluer à la fois les données subjectives et objectives sont les sondages des utilisateurs et les revues post-implantation. Quant aux sondages auprès des utilisateurs, les questionnaires ou les interviews peuvent servir à mesurer la quantité d'information et l'importance de l'assistance que, selon les utilisateurs, le système leur procure (critères subjectifs). Notons ici que cette appréciation comprendrait aussi l'évaluation de toute documentation ou de toute formation fournie avec le système. Les évaluations post-implantation sont essentiellement sommatives et révèlent le succès avec lequel le système exécute les fonctions prévues (critères objectifs).

La plupart des techniques d'évaluation sont empruntées à l'évaluation des logiciels, et, en particulier, à celle des systèmes d'aide la décision. Les systèmes experts tombent sous l'étiquette générale des aides à la décision; le problème qui se pose est le même : comment mesurer l'amélioration dans la prise de décision? Les techniques d'évaluation répondent à des questions qui ressemblent à ceci : "Dans quelle mesure le système facilite-t-il ou complique-t-il le travail de l'utilisateur? Dans quelle mesure facilite-t-il les aspects cognitifs de la prise de décision? Le système aide-t-il à améliorer la qualité globale des décisions prises? Quels critères doit-on évaluer? Comment doit-on les évaluer?

Certaines méthodologies d'évaluation sont basées sur des techniques d'analyse de décision, comme celles des analyses de sensibilité et de valeur attendue. D'autres utilisent l'approche de l'homme rationnel, avec l'hypothèse que l'information parfaite est toujours disponible et que la solution optimale peut être trouvée au moyen de méthodes quantitatives. Les approches incrémentielles sont plus indiquées pour les

systèmes experts. Une de ces approches est PAM (Project Appraisal Methodology) [Leibowitz, 1985]. Celle-ci combine la notation à des méthodes d'évaluation économique où chaque critère sert à évaluer un aspect distinct du système. Si tous les critères sont mutuellement exclusifs, il n'est toutefois pas nécessaire de les évaluer tous pour étudier le système.

Une autre technique d'évaluation des systèmes couramment utilisée est MAUT ou théorie multi-attribut de l'utilité [Adelman, 1986]. Voir l'exemple à l'appendice 1. Les critères sont, selon cette méthode, évalués à l'aide d'un questionnaire de 121 questions, notées de 0 à 10 (0 signifiant "pas du tout d'accord" et 10, "tout à fait d'accord"). Le questionnaire a été validé et donne des résultats fiables. En général, plus la note globale du système est élevée, meilleurs sont les résultats de l'évaluation. Cette approche permet l'évaluation d'un grand nombre de critères et de plusieurs points de vue différents. PAM et MAUT semblent toutes deux être de bonnes techniques pour l'évaluation de systèmes experts.

4.3 Évaluation des systèmes experts

Comment doit-on évaluer les systèmes experts? L'évaluation formative semble être essentielle et a été proposée comme le meilleur moyen d'évaluer les systèmes experts [Hofmeister, 1986]. Toutefois, une brève étude de la manière dont les systèmes experts sont évalués indique que l'évaluation sommative est plus fréquente [Soloway et Littman, 1987]. Comme je l'ai déjà dit, les deux sortes doivent être appliquées si l'on veut une évaluation exhaustive de la performance du système expert.

Les prototypes de systèmes experts en réalité servent d'étude de faisabilité de l'application de la technologie de l'intelligence artificielle à la résolution de problèmes donnés. Un système expert n'est jamais vraiment "arrivé à terme"; il est en évolution continue. Ainsi, l'évaluation sommative, dans le sens strict du terme, est impossible. Toute critique ou suggestion formulée par l'utilisateur n'est pas simplement mise de côté et classée, mais incorporée au système. L'évaluation formative est nécessaire pour guider le développement.

Il est bon de tester le système expert sur le terrain dès que l'on a un prototype opérationnel. L'essai en milieu opérationnel permet en effet la collecte de données

évolutives le plus tôt possible. Ensuite, le système peut être revu par un expert-conseil qui jugera du choix des outils et de la conception générale. Pour vérifier les connaissances, on peut valider le premier ensemble de règles de la base de connaissances en les vérifiant en regard des sources de connaissances factuelles et en confiant à un groupe d'experts la vérification des connaissances heuristiques. Le raisonnement peut être évalué avec un ensemble de jeux d'essai, développé par les utilisateurs en collaboration avec l'ingénieur de connaissances. On peut comparer les résultats obtenus avec le système avec ceux d'experts humains travaillant sur les mêmes jeux d'essai.

Dans ce test préliminaire de la fiabilité du système, on peut vérifier si un même utilisateur obtient des résultats constants à des moments différents et si des personnes différentes travaillant sur le même problème obtiennent les mêmes résultats. Le système expert peut alors être graduellement raffiné et la documentation mise à jour en fonction des changements apportés.

Comme il est impossible d'énumérer et d'évaluer toutes les entrées possibles du système expert, il faut générer un échantillon représentatif de jeux d'essai. Il peut être aussi difficile d'essayer le système avec tous les utilisateurs finals éventuels. On devrait donc choisir également un bon échantillon d'utilisateurs pour évaluer le système.

Dans les deux cas, on doit appliquer les méthodes statistiques appropriées afin d'obtenir des données valides (par exemple, choisir des échantillons de taille convenable et de bonnes techniques d'échantillonnage). Pour vérifier le système, on peut choisir des candidats parmi les utilisateurs finals visés, d'autres parmi les ingénieurs de connaissance, des étudiants universitaires du deuxième cycle, des personnes n'ayant aucune notion d'informatique et des experts d'autre milieu [Krcmar, 1985]. Ces différents types d'utilisateurs devraient fournir un éventail de données de toutes sortes différentes.

Une bonne façon de rassembler des critères d'évaluation consiste à demander à des experts de noter des études de cas ou des décisions prises à partir d'une variété d'attributs. Par exemple, la complexité relative de chaque cas, sa qualité (les risques de situations semblables? a-t-on de la rencontrer de nouveau?), le temps passé par les

experts à noter, etc. Ce type d'analyse de tâches générera un bon éventail de problèmes de types différents pouvant servir à vérifier le système expert.

Quelques systèmes experts sont arrivés au stade de la mise en marché et ont été évalués. Un bref aperçu de certains d'entre eux illustre les méthodes d'évaluation appliquées aujourd'hui [Soloway et Littmann, 1987]. Le premier et le plus connu des systèmes experts, MYCIN, a été évalué avec le jugement d'expert sur l'exactitude des résultats. La performance du système a été comparée en regard de trois groupes : experts, médecins résidents et étudiants en médecine; MYCIN a été trouvé aussi bon ou meilleur que les trois groupes pour résoudre un ensemble de dix problèmes réels complexes. Le critère utilisé a été le pourcentage de diagnostics corrects. Cette évaluation sommative a aussi révélé que les utilisateurs trouvaient le système trop difficile à employer.

Le système INTERNIST a également été évalué avec des techniques sommatives et ses résultats ont été comparés à ceux des médecins. Le système PROSPECTOR a fait l'objet d'une évaluation sommative de son intégrité et de l'organisation de sa base de connaissances, toujours en comparaison avec des experts humains utilisant les mêmes connaissances. Des programmeurs novices ont essayé le système PROUST sur 200 programmes et ont fait une évaluation sommative du pourcentage d'erreurs (de virus) détectées par le tutoriel intelligent. De plus, une évaluation externe des avantages pédagogiques a été réalisée et l'on a trouvé que PROUST donnait aux étudiants un avantage de 16 % aux examens!

R1/XCON est le seul système qui a été évalué avec des techniques d'évaluation formative. Pendant trois ans, des évaluations trimestrielles ont été faites de ce projet de développement d'une durée de 6 ans (avec plus de 6 000 règles dans la base de connaissances). Les critères utilisés ont été la diminution en pourcentage des erreurs factuelles et des règles incorrectes dans la base de connaissances. Ainsi, l'évaluation formative tend à être relative (toujours en termes de degré d'amélioration sur le prototype précédent), tandis que l'évaluation sommative donne un jugement de valeur absolue ou la certification du système expert.

4.3.1 Métrologie des systèmes experts (données objectives)

Peu de travaux ont été faits à ce jour sur le développement d'une métrologie pour l'évaluation formelle des systèmes experts, probablement parce que si peu d'entre eux sont des produits commercialisés. En outre, certaines contributions uniques de systèmes experts méritent d'être évaluées par des experts. Nous pouvons cependant utiliser la métrologie pour spécifier un certain nombre de paramètres objectifs du système expert, qui nous serviraient à définir les objectifs du système, à prévoir les résultats que nous pouvons en attendre et à mesurer les résultats réellement obtenus [Kaisler, 1985]. Des critères quantitatifs ou quantifiables peuvent aussi servir à mesurer l'écart entre les résultats attendus et réels, ainsi qu'à comparer différents systèmes.

Les critères quantitatifs sont particulièrement utiles lorsqu'on doit mesurer le progrès évolutif des systèmes experts dans une évaluation formative. Les deux types généraux de métrologie sont la métrologie des applications, qui est particulière au domaine, et la métrologie technologique, qui traite d'efficience et d'implantation et qui est particulière au noyau ou au langage utilisé pour développer le système. Parmi les catégories métriques qu'il peut être utile de considérer, on compte la complexité de la base de connaissances, l'exécution de la base de connaissances et la métrologie du système.

Avec la complexité de la base de connaissances, on mesure l'ampleur du travail de développement. Les mesures peuvent être déterminées par le nombre d'objets, le nombre de cases par cadre, le nombre de règles, le nombre moyen d'instructions si dans une règle, etc. En nous inspirant encore une fois de l'approche systémique, nous pouvons considérer la base de connaissances comme un sous-système du système expert. La complexité du système est généralement définie comme étant égale à (N-1)/S, N représentant le nombre de noeuds ou de points de décision, et S, le nombre de liaisons entre les noeuds. En la modifiant légèrement, nous pouvons adapter cette formule au schème de représentation des connaissances utilisé, N devenant le nombre d'objets et S, le nombre de schémas par exemple. (L'appendice 2 donne les mesures de complexité des trois bases de connaissances développées pour le système QUARTZ).

La métrologie de l'exécution d'une base de connaissances mesure, entre autres, le temps requis pour le démarrage, la mise à jour et le temps de réponse du système. La

métrologie de l'exécution mesure la vitesse globale de traitement des connaissances, le nombre de règles considérées pour chaque conclusion, la quantité d'informations comprise dans les règles individuelles, le temps moyen de consultation par utilisateur, le nombre de concepts distincts représentés dans la base de connaissances, etc.

Dans l'évaluation quantitative des systèmes experts, nous devons tenir compte d'un certain nombre de points importants, notamment :

- la métrologie n'est pas statique étant donné que le système évolue et se développe
- les outils qui ont servi à élaborer le système doivent aussi être évalués
- le nombre et les types de problèmes que peut résoudre le système doivent être identifiés, évalués quant à la précision et la fiabilité du système
- l'ampleur des changements à apporter à la conception doit être mesurée, avec, par exemple, le nombre de règles par changement
- une analyse des tendances doit être faite à partir d'instantanés incrémentiels du système en évolution (par exemple, un graphe chronologique de la complexité de la base de connaissances).

Ces mesures peuvent nous indiquer si la base de connaissances est trop compliquée ou trop simple, et, par là même, si l'application de la technologie des systèmes experts au problème était opportune, si les utilisateurs passent trop ou trop peu de temps avec le système (ce temps doit se comparer au temps que l'on passe avec les experts humains, soit 20 minutes environ par consultation). Une autre sorte de métrologie consisterait à mesurer l'efficience du génie cognitif en termes de nombre de règles par jour (ou de nombre de jours par règle!). Toutefois, alors que les mesures quantitatives sont nécessaires, elles ne sont cependant pas suffisantes pour évaluer les aspects uniques du système expert. Nous devons également obtenir des données qualitatives ou subjectives.

4.3.2 Critères qualitatifs (données subjectives)

Un ensemble généralement accepté de critères qualitatifs ou subjectifs reste à développer pour évaluer le système expert. Un grand nombre de critères peuvent être empruntés à l'évaluation classique des logiciels, comme la maniabilité, la capacité

d'évolution, la rentabilité, etc. A cette liste, il faudra ajouter des critères spécifiques à la technologie des systèmes experts. Pour classer le grand nombre de critères applicables, nous utiliserons la taxinomie proposée par Krcmar [Krcmar, 1985].

Cette taxinomie reconnaît trois grandes catégories : les aspects techniques (de matériel et de logiciel utilisés pour développer le système), la base de connaissances (la validité des faits et règles du système) et ce que l'on appelle les facteurs environnementaux ou humains (sensibilisation des cadres, l'acceptation par l'utilisateur, analyses coût-bénéfices-risques, etc.). Dans le tableau qui suit, nous élaborons une liste des critères les plus importants dans chaque catégorie.

Tableau 1. Critères qualitatifs d'évaluation des systèmes experts

Aspects techniques

- souplesse du système expert et adaptation aux changements de l'environnement (par exemple, les objectifs du système ne sont plus les mêmes)
- l'addition de connaissances exige-t-elle des changements majeurs?
- aptitude du système à prendre de l'expansion avec l'apport d'expertise et de rétroaction
- fiabilité de fonctionnement du système (par exemple, est-ce qu'il tombe en panne?)
- efficience de l'utilisation des ressources par le système (par exemple, l'utilisation de la mémoire)
- indépendance par rapport au matériel ou maniabilité (le système peut-il tourner sur des configurations de matériel différentes?)
- intelligibilité ou compréhensibilité du système (le code est-il facilement lisible?)
- testabilité (le fonctionnement du système est-il facilement testable?)
- facilité d'interaction avec le système (qualité technique de l'interface)

Base de connaissances

- applicabilité de la base de connaissances (quels problèmes peuvent être résolus?)
- la base est-elle compréhensible pour les utilisateurs comme pour les réalisateurs (par exemple, ambiguité des locutions)
- précision du contenu (généralement déterminée par des experts du domaine)
- qualité des déductions et des avis du système
- exactitude des techniques de raisonnement utilisées
- les résultas produits sont-ils utiles? (par exemple, présentation des rapports)
- facilité d'interaction (par exemple, fonction d'aide)
- qualité non technique de l'interface (par exemple, fenêtres, mise en évidence)
- intégralité de la base de connaissances (y a-t-il des cas non résolus?)
- cohérence de la base de connaissances (par exemple, terminologie, notation uniformes)
- structuration de la base de connaissances (par exemple, est-elle bien structurée?)
- autodescription (y a-t-il assez d'information dans la base de connaissances pour déterminer les objectifs, les hypothèses, les contraintes, l'état à tout moment?)
- les conflits sont-ils résolus de manière adéquate? (par exemple, tous les conflits entre experts ont-ils été résolus ou des métamodèles d'expertise ont-ils été construits? Dans ce dernier cas, les utilisateurs ont-ils le choix de l'expert à consulter dans le système?)
- pouvez-vous faire la différence entre une bonne base de connaissances et un mauvais moteur d'inférence et une base de connaissances médiocre mais avec un bon moteur d'inférence?
- la représentation des connaissances est-elle trop riche? trop simple? compatible avec les organisations des connaissances des experts?

Facteurs environnementaux ou humains

- les utilisateurs acceptent-ils le système?
- ont-ils l'intention de s'en servir?
- ont-ils confiance dans son fonctionnement et dans ses résultats?

- le système aide-t-il les utilisateurs dans leur travail?
- étant donné que les utilisateurs ne sont prêts à s'adapter aux besoins d'aucun système, le système peut-il, lui, s'adapter à l'utilisateur, au contexte, au niveau d'expertise et aux stratégies préférées?
- le système expert peut-il être utilisé dans d'autres applications? par d'autres groupes? (jusqu'à quel point est-ce un produit générique ou spécialisé?)
- le temps de conception convient-il aux développeurs? aux utilisateurs? à la direction?
- le système fonctionne-t-il bien du point de vue des utilisateurs, des ingénieurs de la connaissance, des consultants externes?,
- les suggestions des utilisateurs ont-elles été intégrées dans le système?
- le système est-il rentable?
- quels sont les avantages du système? (par exemple, sauvegarde de l'expertise de l'entreprise, formation, prise de décision meilleure et plus uniforme, meilleure qualité de vie au travail, protection contre les erreurs, gain de temps, meilleure communication entre les utilisateurs humains, aptitude à servir une clientèle plus large)
- quels sont certains des risques associés à l'utilisation du système? (par exemple responsabilité civile)
- combien a coûté le système? (coût du développement, de la livraison, de l'entretien).

Il est aussi important de connaître les principales raisons pour lesquelles les systèmes experts échouent. Le critère d'applicabilité semble jouer le plus grand rôle dans le succès ou l'échec de ces systèmes. La raison pour laquelle la plupart des systèmes ne sont jamais implantés avec succès est l'inapplicabilité du problème traité. Ou bien celui-ci a été mal compris, ou bien il ne requiert que le sens commun; il n'existe peut-être pas de solution au problème (de l'avis même des experts humains); ou bien nous faisons face à une situation en vase clos, et de ce fait c'est-à-dire, le système ne sait pas ce qu'il ne sait pas (contrairement au médecin, par exemple, qui sait quand vous recommander d'aller voir un autre spécialiste).

L'acceptation de l'utilisateur est le dernier obstacle décisif a franchir en regard des systèmes experts. Afin de maximiser les chances de succès, le système doit être conçu de manière à ce qu'on puisse le soumettre à des tests; les utilisateurs doivent faire confiance au système et ne pas penser que le système les remplacera au travail.

D'autres raisons peuvent influencer les utilisateurs à ne pas accepter le système expert, entre autres :

- la méconnaissance de la technologie informatique
- la difficulté à s'adapter à l'interface utilisateur
- la conviction que les humains peuvent faire le travail mieux que le système
- le sentiment qu'ils doivent s'en servir que pour les cas très difficiles
- la tendance à se rappeler les problèmes (même très anodins) qu'ils ont déjà eus avec le système
- le manque de confiance ou trop de confiance dans les résultats
- la diminution de la satisfaction au travail.

Il a de tout temps été prouvé [Lane, 1986] que l'introduction de toute innovation dans un système donné doit tenir compte de la volonté des utilisateurs visés à accepter le changement et à l'intégrer à la structure de leur travail. Il y a encore beaucoup de méfiance à l'endroit des ordinateurs et la question la plus critique entre toutes est peut-être le degré de transparence ou d'opacité du processus de raisonnement du système expert. Tant que les utilisateurs ont l'impression de pouvoir accéder aisément au raisonnement interne du système, ils l'accepteront plus volontiers. D'où l'importance des fonctions d'explication du système (son aptitude à répondre aux "comment" et "pourquoi").

4.4 Conclusion

L'évaluation complète d'un système expert exige des mesures à la fois objectives et subjectives. Les mesures objectives comprennent l'analyse des erreurs, le temps passé sur les tâches et les tendances d'utilisation, tandis que les mesures subjectives ont trait à la fiabilité du système, à son utilité, à son dogmatisme, à la manière adéquate ou non dont il justifie ses conclusions, etc. Comme le système expert a autant besoin de l'acceptation de l'utilisateur que de performance pour réussir, il faut en faire une évaluation à la fois formative et sommative. Actuellement, il reste, semble-t-il, beaucoup de recherche à faire pour développer les mesures quantitatives et qualitatives qui s'appliquent aux systèmes experts. Une méthode systématique de saisir et d'intégrer la rétroaction diagnostique et prescriptive de l'utilisateur doit être mise au point pour l'évaluation des systèmes experts. Une réalisation intéressante à ce

propos est EVA (Expert System Validation Associate), qui est un système de validation automatique des systèmes experts [Stachowitz et Combs, 1987].

5. ANALYSE ET TRAVAUX FUTURS

5.1. Avantages démontrés

QUARTZ a déjà démontré son utilité à sauvegarder l'expertise de l'entreprise, puisque plusieurs des experts de la première heure ne travaillent plus à l'évaluation des projets EDER. Leur expertise particulière ainsi que leur perspective générale sur l'analyse des propositions font aujourd'hui partie de la base de connaissances de QUARTZ. Aussi, QUARTZ a servi avec succès d'étude de faisabilité de l'utilisation des systèmes experts pour surveiller le cycle de vie d'un projet, de même que, dans cette recherche, d'un système expert devant aider les analystes à l'analyse et la sélection des projets admissibles aux programmes de subvention du gouvernement.

Un certain nombre de possibilités semblent s'ouvrir au système QUARTZ. Celui-ci peut être modifié et devenir un système expert pour l'analyse des projets soumis au programme EDER du Manitoba, par exemple, ou pour l'analyse interne à notre propre centre de recherche. Il est aussi concevable que QUARTZ puisse être utilisé directement par les entreprises dans la préparation de leurs soumissions. Cette possibilité s'inscrirait dans le sens des politiques gouvernementales d'accès du public à l'information.

Finalement, la base de connaissances de QUARTZ aide à produire des analyses plus uniformes et plus exhaustives et des recommandations qui sont basées sur une analyse plus systématique de tous les critères qualitatifs et quantitatifs utiles. Cette expertise formalisée peut aussi être mise à la disposition des analystes débutants comme aide ou outil de formation. Le groupe d'experts de Québec a accepté de poursuivre l'étude de cette application possible de QUARTZ. Le principal avantage tant attendu du système QUARTZ est d'améliorer de façon certaine l'efficience et la qualité de la rétroaction dont peuvent bénéficier les entreprises intéressées.

Les avantages évoqués ici seront évalués au cours du prochain trimestre, selon les méthodologies décrites dans ce rapport.

5.2 Projets de travaux

Les recherches effectuées, ce dernier trimestre, ont servi à formuler une base théorique solide pour l'évaluation formative des prototypes QUARTZ. L'approche systémique de l'évaluation - ainsi que le point de vue qu'un système expert doit être viable - semble être une méthode pragmatique justifiée pour le développement et la validation des systèmes experts. L'évaluation du système QUARTZ se fera ainsi selon l'option proposée d'intégrer le processus d'évaluation dans la conception du système et avec les critères quantitatifs et qualitatifs déterminés à l'appendice 1. Dès qu'un prototype aura été accepté par l'utilisateur, une évaluation sommative sera réalisée sur cette version "définitive" de QUARTZ.

Les leçons tirées de cette étude des méthodes d'évaluation indiquent que QUARTZ devrait être testé selon quatre niveaux différents au moins. Ces niveaux sont, dans l'ordre croissant de généralité :

1. base de connaissances de faits et règles; mécanisme d'inférence; interface utilisateur
2. le système expert en entier - ses entrées, sa capacité de traitement, ses sorties
3. sous-système d'analyse du programme EDER - efficience, qualité
4. le processus décisionnel EDER en entier.

Parmi les jalons posés, nous comptons atteindre les réalisations suivantes au prochain trimestre:

- la validation de la base de connaissances à l'aide des premiers experts (en autres, d'un expert de notre propre centre de recherche)
- l'évaluation de la performance du système, du point de vue des utilisateurs (questionnaire et interviews)
- la métrologie du système afin d'estimer le travail de développement requis.

La prochaine étape consiste à dresser un plan d'évaluation pour QUARTZ. Quelques-uns des repères principaux prévus pour les prochains mois seront les essais de validation et de fiabilité du questionnaire de rétroaction, l'incorporation des suggestions des utilisateurs et des corrections et la livraison du deuxième prototype opérationnel.

6. RÉFÉRENCES

Adelman, L. (1986). On the basis of what criteria should decision support systems be evaluated? Proceedings Expert Systems in Government Symposium, Washington, D.C. pp. 348-350.

Bell, M. (1985). Why Expert Systems Fail. Journal of Operational Research Society, 36, 7, 613-619.

Borg, W. and Gall, M. (1983). Educational Research (4th ed.) New York : Longman, Inc.

Beer, S. (1979). The Heart of Entreprise. Devon : Pitman Press.

Brixius, L. (1984). Artificial Intelligence Applications in Civil Government. Proceedings IEEE EASCON'84 conference. pp. 45-49.

Dalkir, K. et Muzard, J. (1987) QUARTZ : système expert d'aide à l'analyse et à l'évaluation des projets. Actes de la conférence IEEE Montech COMPIN'87. Montréal, Québec. pages 208 à 210.

Defense Systems, Inc. The Decision Aid Measurement and Evaluation (DAME) Methodology Assessment of the Integrated Tactical Decision Aid (ITDA). 29 Apr. 1985.

Gallant, S. and Balachandra, R. (1986). Using Automated Techniques to Generate an Expert System for R & D Project Monitoring. IFAC conference on Economics and Artificial Intelligence, Aix-en-Provence, France. pp. 61-66.

Giezl, L. (1987). The Expert System Applicability Question. Proceedings, Artificial Intelligence and Simulation conference, San Diego, CA. 17-20.

Gordon S. (1988). The Human Factor in Expert Systems. AI Expert, January, 1988, pp. 55-59.

Hofmeister, A. (1986). Formative Evaluation in the Development and Validation of Expert Systems in Education. Comput. Intell., 2, 65-67.

Kaisler, S. (1985). Expert System Metrics. Proceedings Expert Systems in Government Symposiun, Washington, D.C. pp. 114-119.

Krcmar, H. (1985). Enterprise-wide Information Management: Expert Systems for Information Management. IBM LA Scientific Centre, Report G320-2767.

Lane, N. (1986). Global Issues in the Evaluation of Expert Systems. Proceedings IEEE Conference on Systems, Man and Cybernetics, Alexandria, VA. pp. 121-125.

Leblanc, L. (1987). An Analysis of Critical Success Factors for a Public Sector Decision Support System. Evaluation Review, 11, 1, 73-83.

Liebowitz, J. (1985). Evaluation of Expert Systems: an approach and case study. Proceedings 2nd Annual Conference on Artificial Intelligence Applications: the Engineering of Knowledge-based Systems. Miami Beach, Florida, December 1985.

NITAS (1986). A Reasoning System for the Guidance of Technological Transfer. IFAC Conference on Economics and Artificial Intelligence, Aix-en-Provence, France. pp. 183-186.

Soloway, E. and Littman, D. (1987). Expert System Evaluation. Tutorial, IJCA187 conference, Milan, Italy.

Stachowitz, R. and Combs, J. (1987). Validation of Expert Systems. Proceedings of the 20th Annual Hawaii International Conference on System Sciences, 1987

7. APPENDICE I. HIÉRARCHIE DES CRITÈRES D'ÉVALUATION DE LA THÉORIE MULTI-ATTRIBUT DE L'UTILITÉ (MAUT)

[Tiré de Adelman, L. (1986). On the Basis of what Criteria Should Decision Support Systems Be Evaluated? Procs. ESIG Conference.]

0 utilité globale (6)

1. interface système/utilisateur

1. rapport avec le personnel
   1. formation et expérience technique (3)
   2. style de travail, charge de travail et intérêt (4)
   3. besoins opérationnels (5)
2. caractéristiques du système
   1. caractéristiques générales
      - facilité d'emploi (4)
      - compréhension des processus du système (3)
      - facilité d'initiation (2)
      - temps de réponse (2)
   2. caractéristiques particulières
      - interface utilisateur (2)
      - intégrité des fichiers de données (3)
      - précision des jugements experts (2)
      - aptitude à modifier les jugements (2)
      - compréhension des algorithmes du système (2)
      - utilité des graphes (2)
      - utilité des imprimés (2)
      - compréhension du texte (2)

2. interface organisation/utilisateur-système

1. facteurs d'efficience
   1. acceptabilité des temps pour :
      - l'accomplissement des tâches (3)
      - la gestion des données (2)
      - la configuration du système (2)
   2. fiabilité perçue dans des conditions réelles (2)

disponibilité des compétences (2)
disponibilité du matériel (2)

2. rapport avec les facteurs organisationnels
   1. effet sur la structure et les procédures de l'organisation (2)
   2 effet sur les postes d'autres personnes dans l'organisation
   acceptabilité politique (2) charge de travail d'autres employés (2)
   3. effet sur le flux d'information (2)
   4. répercussions indirectes
   valeur dans l'exécution d'autres tâches (2)
   valeur pour les organisations affiliées (2)
   valeur pour la formation (2)

3. **Interface organisation/environnement**
   1. précision des décisions (8)
   2. rapport entre l'approche technique du système et les aspects du problème(7)
   3. qualité du processus de décision (2)
      1. qualité du plan d'incorporation des jugements (2)
      2. nombre de solutions (2)
      3. comparaison des différentes solutions (2)
      4. évaluation des conséquences des différentes solution(3)
      5. réexamen du processus décisionnel (3)
      6. utilisation de l'information (3)
      7. considération d'un plan d'implantation et de mesure d'urgence (2)
      8. effet sur les discussions de groupe (3)
      9. effet sur la confiance du décideur (2)

Note : les chiffres entre parenthèses indiquent le nombre de questions utilisées dans le questionnaire pour évaluer le critère.

7.1 APPENDICE II METROLOGIE DE LA BASE DE CONNAISSANCE DE QUARTZ

Date	Nb d'objets	Nb de schémas	Complexité	Nb de règles
FÉVRIER 87	83	30	2.73	15
MARS 87	58	17	3.35	108
MAI 87	82	21	3.86	260

COMPLEXITÉ STRUCTURELLE

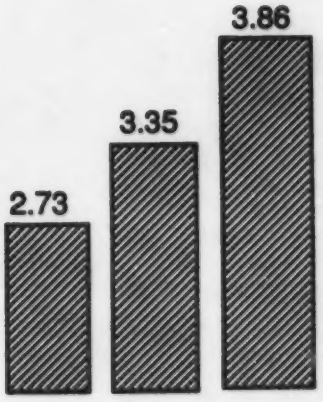

NOMBRE DE REGLES